# 学術・技術論文

# パーティクルフィルタを利用した自己位置推定に生じる 致命的な推定誤りからの回復法

# Recovery Methods for Fatal Estimation Errors on Monte Carlo Localization

Ryuichi Ueda\*<sup>1</sup>, Tamio Arai\*<sup>1</sup>, Kazunori Asanuma\*<sup>2</sup>, Kazunori Umeda\*<sup>3</sup> and Hisashi Osumi\*<sup>3</sup>

Though Monte Carlo localization is a popular method for mobile robot localization, it requires a method for recovery of large estimation error in itself. In this paper, a recovery method, which is named an expansion resetting method, is newly proposed. The combination of the expansion resetting method and the sensor resetting method, which is a typical resetting method, is also proposed. We then compared our methods and others in a simulated RoboCup environment. Typical accidents for mobile robots were produced in the simulator during trials. We could verify that the expansion resetting method was effective for recovery from small irregular changes of a robot's pose, and that the combination method could deal with both large and small irregular changes.

**Key Words**: Bayes Filters, Monte Carlo Localization, Kidnapped Robot Problems, Expansion Resettings, Sensor Resettings

# 1. は じ め に

近年,既知環境下での移動ロボットの自己位置推定に,パーティクルフィルタを適用する方法の有効性が示されている.この方法は,ロボットの姿勢を示すパラメータ(位置(x,y),方向 $\theta$ )で張られる空間に,確率を重みとして持つ点(パーティクル)を多数分布させる.そして, $xy\theta$  空間の任意の領域にロボットが存在する確率を,その領域中に存在するパーティクルの重みの合計として近似表現する.パーティクルの分布はデッドレコニングによって移動し,センサ情報が入力されるとベイズの公式によりパーティクルの重みが変更される.この手法はMonte Carlo localization (MCL)と呼ばれ [6] ~ [8] ,ロボットサッカーのように実時間性が要求される用途にも多く使用されている [5] [11] [12] [15] .

MCL には、なんらかのアクシデントで真の姿勢の周囲にパーティクルが存在しない状態が起きた場合、ベイズの公式が適用不可能となる問題がある、アクシデントとしては、ロボットが人間等によって強制移動させられる誘拐ロボット問題(kidnapped

robot problem )[9] [14] や,スリップ・衝突による想定外の姿勢変化などが挙げられる。また,実装した環境地図の細かい寸法が実際と異なるということもある [18].これらのような事前に想定されなかった,あるいはできない事象に対して,MCL は時に非常に脆弱である。しかし逆にいえば,上記の問題の発生後にパーティクルを真値の周辺に戻すことができれば,ロバストな推定が可能となる。本論文では,「真の姿勢の周囲にパーティクルが存在しない状態」を「誘拐状態」と呼び,誘拐状態からMCL が実行可能な状態に推定を回復する方法を扱う。

回復方法には,長距離の強制移動を伴う誘拐ロボット問題(遠距離の誘拐状態)に対応することが求められる.また,MCLにはパーティクルの分布から真の姿勢がわずかにずれただけで,長時間その誤差が解消されなかったり,逆に拡大する性質がある.したがって,長距離の誘拐だけではなく,スリップ・衝突による「近距離の誘拐状態」に対しても迅速に解消することも求められる.

誘拐状態の解消法として,あるセンサ情報がパーティクルの分布と大きく矛盾するとき,パーティクルの分布を作成し直すという方法がある.Lenser らの提案したセンサリセット法 [12] (sensor resettings,以下 SR 法)は,この考え方に基づいている.この手法は,センサ情報から得られる真の姿勢の存在確率分布と,パーティクルの示す存在確率分布の重みつき和をとって,その分布に基づくようにパーティクルを再配置する.Thrun らは,SR 法はベイズの定理に反する方法であって理論的な裏づけ

原稿受付 2004年6月25日

<sup>\*1</sup>東京大学大学院工学系研究科

 $<sup>*^2</sup>$ 日立ソフトウェアエンジニアリング株式会社

<sup>\*3</sup>中央大学理工学研究科

 $<sup>^{*1}</sup>$ The university of Tokyo

 $<sup>^{*2}</sup>$ Hitachi Software Engineering Co.,Ltd.

<sup>\*3</sup>Chuo university

が乏しいと指摘している [14]. しかし, どのような数理モデルでも想定外の事象を扱うことは理論上できない、そのため, SR法のような手続きは, 想定外の事象が起こる以上, 必要となる.

SR 法には,センサ情報の雑音で不必要なリセットを起こす問題がある.また,近距離の誘拐状態に対してパーティクルの分布を広げすぎるためむだが大きい.特に,センサ情報から一意に姿勢が決まらない場合(これは MCL がよく用いられる場合である)に,この傾向が大きくなる.前者の問題に対し,矛盾が連続したら SR 法を実行する方法が提案されている[5][9].

この改良法のほかに,前者の問題に対しては,不必要なリセットによる悪影響を最小限に抑えるという方針も考えられる.この方針からは,パーティクルの平均姿勢等,分布が与える重要な推定情報を残しつつ,パーティクルの分布を拡大する(膨張させる)という新たな手法が考えられる.また,この手法は誘拐以前の姿勢付近にパーティクルを供給するため,結果的に近距離の誘拐状態に対しても有効である可能性がある.

#### そこで,本論文では

●パーティクルの分布を膨張させるリセット法:膨張リセット法 (expansion resettings 法, ER 法)

の提案を行う.ただし,パーティクルが広範囲に分布するときには,分布が与える推定情報の重要性が低いため,ER 法の意義は薄くなると予想される.そこでさらに

・パーティクルが広範囲に分布するときには SR 法 , それ以 外のときには ER 法を用いる手法

#### の提案を行う.また,

● SR 法とその改良法 , 提案した 2 手法の実装・比較評価を行う . 評価は , ロボカップ 4 足ロボットリーグ [16] [17] 環境を模したシミュレータ [1] で行う . シミュレータを用いるのは , 実環境・実機では様々な誤差要因が複合的に生じ , 何がどの手法にとって問題になるのかを特定しにくいからである .

以後,まず2章において扱う問題について明確にし,3章でそれを解決するための従来手法,提案する手法を説明する.4章ではシミュレーション方法について説明し,リセット法の比較評価を行い,考察を行う.5章で本論文をまとめる.

# 2. Monte Carlo localization と誘拐ロボット問題

ここでは, MCL の理論的背景と MCL のアルゴリズムを説明する.その上で, MCL の持つ問題点を示す.

#### 2.1 Markov localization

以下に説明する定式化は Markov localization (  $\rm ML$  ) と呼ばれ, $\rm MCL$  はこれらの数式に基づいて実装される.従来, $\rm ML$  は  $xy\theta$  空間を格子状に区切り,各区分に確率を割り当てる方法で実装されることが多かった [2] [3] .

移動ロボットの姿勢が  ${f Fig. 1}$   $({f a})$  のように , ある平面上の xy 座標上での位置 (x,y) と向き  $\theta$  で表されるとする . ロボットの 真の姿勢 ( 真値 ) を  $xy\theta$  空間中の点  $\ell^*$  で表し , ロボットが取りうるすべての姿勢  $\ell^*$  の集合を  $\mathcal X$  とする . また , 次の記号 :

- •離散時間:T = 0, 1, 2, ..., t 1, t, t + 1, ...
- $\bullet T = t$  で得られるセンサ情報:  $d_t$
- $\bullet t \leq T < t+1$  におけるロボットの行動: $a_t$

を定義する.これらを Fig. 1 (b) に示す.このとき, 任意の集

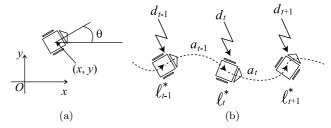


Fig. 1 Definition of symbols (a): parameters for pose  $\ell_t^*$  (b): sensor information d, action a, and pose  $\ell^*$ 

# 合 $Y \subset \mathcal{X}$ にロボットの姿勢が存在する確率

$$B_t(Y) = \int_Y b_t(\ell)d\ell = \Pr\{\ell_t^* \in Y | d_t, a_{t-1}, d_{t-1}, a_{t-2}, d_{t-2}, \dots, d_1, a_0, b_0\}$$
(1)

を求めることを考える.ここで,確率密度関数  $b_t$  は  $\forall \ell \in \mathcal{X}$  に対して  $\ell = \ell_t^*$  である確率密度を与えるものとする.

ここで,次の確率モデルが事前に計測可能であるとする.

- 移動モデル  $p(\ell|\ell',a)$ : ある時刻に姿勢が  $\ell'$  で行動 a を実行したとき,次の時刻に姿勢が  $\ell$  となる確率密度
- センサ情報モデル  $P(d|\ell)$ : 姿勢が  $\ell$  のときにセンサ情報 d が得られる確率

ここで d の種類は可算有限個とした.このとき,

$$\hat{b}_{t}(\ell) = \int_{\mathcal{X}} p(\ell|\ell', a_{t-1}) b_{t-1}(\ell') d\ell'$$
 (2)

$$b_t(\ell) = \frac{P(d_t|\ell)\hat{b}_t(\ell)}{\int_{\mathcal{X}} P(d_t|\ell')\hat{b}_t(\ell')d\ell'}$$
(3)

で  $b_t$  を求めることができる.式(2)と式(3)は,それぞれマルコフ過程とベイズの公式を表している.

# 2.2 Monte Carlo localization

MCL は, $xy\theta$  空間中に多数の点(パーティクル)を散布し,各パーティクルに対して重みを持たせて確率密度関数  $\hat{b}_t,b_t$ を近似計算する方法である  $[6]\sim[8]$ .パーティクル  $s_t^{(i)}$   $(i=1,2,\ldots,N)$  は,おのおのがパラメータとして姿勢  $\ell_t^{(i)}=(x_t^{(i)},y_t^{(i)},\theta_t^{(i)})$  と重み  $w_t^{(i)}$  を持ち, $s_t^{(i)}=(\ell_t^{(i)},w_t^{(i)})$  と表現される.一般に,パーティクル数 N が大きくなるほど,近似精度は高くなる.

ロボットの移動  $a_{t-1}$  をパーティクルの分布に反映するためには,次の手続きを  $i=1,2\dots,N$  について行い, $s_t^{(i)}(i=1,2\dots,N)$  を生成する.

- (1) $s_{t-1}^{(j)}(j=1,2\ldots,N)$  から,重み  $w_{t-1}^{(k)}$  の示す確率に従って  $s_{t-1}^{(k)}$  を選択
- (2) $p(\ell|\ell_{t-1}^{(k)},a_{t-1})$  に従って  $\ell$  を選択( $\ell_{t-1}^{(k)}:s_{t-1}^{(k)}$  の姿勢)
- (3) パーティクル  $s_t^{(i)} = (\ell, 1/N)$  を生成
- これらの手続きは,式(2)を近似している.

センサ情報  $d_t$  を反映させるには,まず式(3)の分母を

$$\alpha = \sum_{i=1}^{N} P(d_t | \ell_t^{(i)}) w_t^{(i)}$$
 (4)

という近似で求め, i = 1, 2..., N に対し,

$$w_t^{(i)} \leftarrow P(d_t | \ell_t^{(i)}) w_t^{(i)} / \alpha \tag{5}$$

という手続き重みを変更する.この手続きは式(3)の近似である.

#### 2.3 誘拐状態

誘拐ロボット問題は,単にロボットが瞬間移動するという比喩だけで説明されることが多い[9]. 本論文では,「誘拐」の結果生じる状態を,真値  $\ell^*$  近傍の確率がほとんど 0 になっている状態と解釈して,

$$B_t(Y) = \int_Y \hat{b}_t(\ell) d\ell \approx 0 \quad (\ell_t^* \in Y \subset \mathcal{X})$$
 (6)

と定式化する.また,このような状態を誘拐状態と呼ぶ.ベイズの公式は,曖昧な事前知識を新しい情報によって確かにするために使用するもので,誤っている $\hat{b}_t$ を棄却する機能を有していない.そのため,センサ情報に基づいて誘拐状態を解消するためには別の枠組みが必要となる.

式(2)には  $\hat{b}_t(\ell)$  を曖昧にする作用があるため,ある程度までの確率分布からの  $\ell^*$  の逸脱は,解消されることが期待できる.しかし,「誘拐」によってロボットが全く異なる姿勢にされた場合には,この作用は全く期待できない.逸脱の程度がわずかな場合でも,精度のよいデッドレコニングが可能なロボットほど解消可能な逸脱の程度は小さくなり,解消までに長時間かかるようになる.

MCL の場合には、パーティクルが真値  $\ell^*$  周辺に存在しなくなると  $\ell^*$  周辺の確率分布を近似できなくなるため、誘拐状態はさらに深刻な問題となる.この場合、ロボットの移動によってパーティクルが拡散し、 $\ell^*$  までパーティクルの分布範囲が届くまでは、真値  $\ell^*$  周辺に対してセンサ情報が反映できない.

ML, MCL に悪影響を与えるアクシデントは環境やロボット毎に無数にあるが、そのうち突発性のもの(ロボットの行動時間に対して発生している時間がわずかのもの)によって、その後の推定が困難になる場合はすべて式(6)で表現できる。そこで、誘拐状態に対処する方法があれば、あらゆる突発的なアクシデントに対してロバストな自己位置推定が可能となる。

# 3. リセット法

ML の枠組み内で上記の問題を解決する場合,センサ情報やデッドレコニングの精度,推定結果を実際より悪く見積もって推定を曖昧にする方法がある.例えばファジー推論を用いた[4]などが存在するが,この方法は推定精度を犠牲にする.平常時の精度を落とさないためには,誘拐状態が起きた場合にのみ,例外的な手続きを発動することが望ましい.

そこで,(1) 誘拐状態が検知されると推定を止める,(2) なんらかの方法で初期の確率密度関数  $b_0$  を作成し,推定を再開する,という手続き「リセット」を考える.ML には  $b_0$  の与え方に関して制約がないため,リセットが ML に対して矛盾を生じるということはない.

リセットに相当する手法は MCL で使用するためにこれまでに二つ提案されている [9] [12] . 以下では基本的な方法として,従来の方法二つと,新たに提案する方法一つを説明する.さらに,これらを組み合わせる方法一つを提案する.

#### 3.1 センサリセット

センサリセット (以下 SR 法)[12] は ,式 (4) の  $\alpha$  で矛盾を検知する .  $\alpha$  から ,次の値

$$\beta = 1 - \alpha/\alpha_{\rm th}$$
 ( $\alpha_{\rm th}$ : 正の定数) (7)

を計算し、 $\beta > 0$  となったとき確率密度関数を

$$\hat{b}_{\text{0new}}(\ell) = \frac{1}{1+\beta} \hat{b}_t(\ell) + \frac{\beta}{1+\beta} p(\ell|d_t) \tag{8}$$

で初期化する.ここで, $p(\ell|d_t)$  はセンサ情報  $d_t$  が得られたときに  $\ell=\ell_t^*$  となる確率密度で,事前に計測されているとする.つまり,もとのパーティクルの分布とセンサ情報から得られる分布を合計した確率分布を初期の分布として,推定を再開する.パーティクルは,この確率密度関数を近似するように再配置される.

#### 3.2 履歴センサリセット

SR 法では , 確率モデル  $P(d|\ell)$  が想定しない雑音がセンサ情報に一度でも発生した場合 , むだなリセットが発生する . そこで , 文献 [5] [9] では , 以下の式で値  $\beta$  を計算する方法が提案されている .

$$\alpha_{\text{long}} \longleftarrow \eta_{\text{long}} \alpha + (1 - \eta_{\text{long}}) \alpha_{\text{long}}$$
 (9)

$$\alpha_{\rm short} \longleftarrow \eta_{\rm short} \alpha + (1 - \eta_{\rm short}) \alpha_{\rm short}$$
 (10)

$$\beta = 1 - \alpha_{\text{short}} / (\alpha_{\text{long}} \alpha_{\text{th}}), \tag{11}$$

ここで,定数  $\eta_{\mathrm{long}}, \eta_{\mathrm{short}}$  は  $0 \leq \eta_{\mathrm{long}} \ll \eta_{\mathrm{short}} \leq 1$  を満たすとする. $\alpha_{\mathrm{short}}/\alpha_{\mathrm{long}}$  は, $\alpha$  が続けて小さい値をとり続けて,初めて  $\alpha_{\mathrm{th}}$  よりも小さくなる.そのため,1 回のセンサ情報の誤りだけではリセットが起きない.本論文では,この方法を履歴センサリセット(hysteresis sensor resettings,HSR)と呼ぶ.この手法は,過去のセンサ情報・行動の履歴を含んでいる $\hat{b}_t$  を,一つのセンサ情報のみで棄却する損失を防いでいると解釈できる.

#### 3.3 膨張リセット

HSR 法とは別のむだなリセットへの対応策として,リセットが起きた場合に,その影響を最小限に抑えるという方針が考えられる.そこで,推定姿勢を変化させずにリセットする「膨張リセット」(expansion resettings,以下では ER 法と呼ぶ)を新たに提案する.ER 法は,式(7)で  $\beta$  を計算し, $\beta$  > 0 のとき,

$$\hat{b}_{0\text{new}} = f[\hat{b}_t] \tag{12}$$

でリセットをかける.この式は,単に b を初期化するために  $\hat{b}_t$  のみを用いるということを示しているにすぎず,重要なのはこの式中の写像 f に次のような性質を持たせることである.

- $\bullet \hat{b}_t$  を , その極値点をなるべく変えず曖昧にする
- ullet 任意の  $\hat{b}_t$  は数回連続 f で変換すると  $\mathcal X$  内で一様な確率 密度関数となる

上式は , センサ情報が入って  $\beta \leq 0$  であるたびに適用されることとする .

 $\mathrm{MCL}$  では , f はパーティクルを拡散させる手続きとして実装できる . 簡単な実装例としては ,  $\mathrm{Fig.2}$  のように , パーティクルの存在範囲を求めておき , リセットが起こるたびにその範囲に接する直方体中にパーティクルを配置する方法が考えられる . この

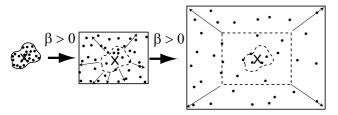


Fig. 2 Expansion resettings (an example in a 2-d space)

直方体の体積を指数乗的に大きくすることで,近距離の誘拐には小さな膨張,遠距離の誘拐には大きな膨張で対応可能である.

この手法も,HSR 法と同様,一度のセンサ情報  $d_t$  で  $\hat{b}_t$  の情報の多くを棄却することを防ぐ効果がある.さらに, $\hat{b}_t$  の分布を大きく変える前に  $\hat{b}_t$  の分布周辺から探索を行うため,近距離の誘拐状態に対して HSR 法よりも有効である.一方 ER 法は,で  $\hat{b}_{\mathrm{0new}}$  の作成に,新たなセンサ情報  $d_t$  を利用することを放棄しているともいえる. $\hat{b}_t$  の分布が広範囲であるほど  $\hat{b}_t$  は情報量が少なく,新たな情報である  $d_t$  を無視する損失が大きくなり,この放棄による損失は大きくなると予測される.

#### 3.4 膨張+センサリセット

上記の予測から, $\hat{b}_t(\ell)$  と  $p(\ell|d_t)$  の情報エントロピーなどの 統計量を大小比較して, $\operatorname{SR}$  法と  $\operatorname{ER}$  法を使い分けるリセット 法が考えられる.しかしここでは複雑な手法を避け,閾値処理 で  $\operatorname{SR}$  法と  $\operatorname{ER}$  法を使い分ける手法を提案する.

 $ullet \hat{b}_t(\ell)$  に関する分散 , 共分散等の統計量がある閾値範囲内のとき  $\mathrm{ER}$  法 , それ以外のときは  $\mathrm{SR}$  法

この手法を  $\mathrm{SR}+\mathrm{ER}$  法と記述する.これにより,近距離の誘拐状態に対しては, $\hat{b}_t(\ell)$  の持つ情報を利用して効率よく誘拐状態が解消できる.一方,遠距離の誘拐状態に対しては, $\mathrm{SR}$  法と同じ閾値  $\alpha_{\mathrm{th}}$  を用いた場合には,数回のむだな膨張リセットが必要となって解消が遅れる.しかし,後のシミュレーションで示すように, $\mathrm{SR}+\mathrm{ER}$  法では  $\mathrm{SR}$  法より  $\alpha_{\mathrm{th}}$  を大きくできるため,一概に  $\mathrm{SR}+\mathrm{ER}$  法が遠距離の誘拐状態に不利とはいえない.

# 4. シミュレーション

ロボカップ 4 足ロボットリーグ [16] [17] の環境を模したシミュレータ [1] で上記のリセット方法を比較する.シミュレーションで比較するのは,実環境では複合して起こる誤差要因を個別に再現できるため,各誤差要因に対するリセット法の挙動を観測することができるからである.

4 足口ボットリーグでは ,  $\mathbf{Fig. 3}$  (a) に見られる自律型 4 脚口ボット ERS-210 が用いられ ,  $\mathbf{Fig. 3}$  (c) に見られるフィールド上でサッカーが行われている . このロボットは各脚と頭部に各 3 自由度を有し , 計算資源として MIPS 192 [MHz] と 32 [MB] の DRAM が内蔵されている . 主要なセンサは頭部の CMOS カメラ (18 万画素 ) であり , このカメラから 40 [ms] ごとに  $176 \times 144$  画素 , 256 階調の YCrCb カラー画像がメモリに転送される .

筆者らの開発したシミュレータ [1] は, OpenGL によってロボットの視点から得られる画像を構築し, 仮想ロボットに実機と同じように画像処理させて行動決定させる構造になっている.

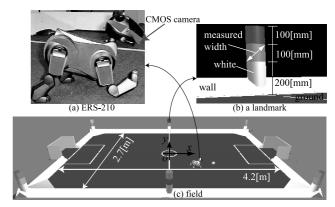


Fig. 3 Environment of RoboCup four legged robot league

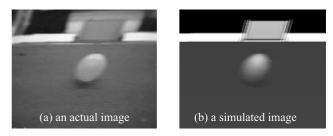


Fig. 4 Simulation of the robot's CMOS camera [1]

当リーグ既存のシミュレータ [10] [13] と異なり,この画像にはカメラのレンズ特性(収差・熱雑音・周辺減光・にじみなど)が忠実に再現されており,センサ情報がばらつくようになっている.Fig. 4 はシミュレータと実機から得られる画像の比較の例である.双方の画像にはボールが歪んで映っているが,これは,カメラが急激に動くときに見られる現象である.

#### 4.1 実装

# 4.1.1 センサ情報に関する確率モデルの実装

位置の情報は, $\operatorname{Fig.3}$  に見られる 6 個のランドマーク( $i=1,2,\ldots,6$  と  $\operatorname{id}$  を付ける)から得られる.ランドマークは  $\operatorname{Fig.3}$  (b) に見られる円筒で,色の違いで互いに識別できる.仮想ロボットには,仮想画像に映ったランドマークを識別し,自身からの方向  $\hat{\varphi}$  [ $\operatorname{deg}$ ] と画像中の幅 h [ $\operatorname{pixel}$ ]( $\operatorname{Fig.3}$  (b) 中の矢印の部分)を計測するアルゴリズムを実装する.姿勢  $\ell$  であるロボットからのランドマーク( $\operatorname{id:}i$ )の真の方向,真の幅をそれぞれ  $\varphi^*(\ell), r(\ell)$  とするとき,センサ情報モデルを

$$P(d|\ell) = P(h, \hat{\varphi}|\ell) = P(\hat{\varphi} - \varphi_i^*(\ell))P(h|r_i(\ell))$$
 (13)

で構築する  $.\hat{\varphi}$  , h のばらつき方と  $\ell$  は無相関であると仮定する . センサ情報モデルを得るために , 仮想ロボットをランダムに歩行させて , ランドマークの計測が行われた場合に  $\ell$  と  $\hat{\varphi}$  , h を記録した . 記録から作成した確率モデルを  $\mathbf{Fig.5}$  に示す . この図は , 7 万回の計測に基づいて作成されており , 頻度は  $\hat{\varphi}-\varphi^*(\ell)$  , r , h をそれぞれ 1 [deg] , 100 [mm] , 3 [pixel] ずつ区切って数えられた . これらの区間の幅はさらに小さくすることもできるが , 実機で計測実験を行い , センサ情報モデルを作成する際の手間を考えると限界に近い値である . 式 (5) で用いるため、この度数表をロボットに実装した . また , 式 (8) で用いるために $p(\ell|d)$  に関する度数表も実装した .

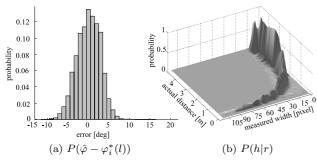


Fig. 5 Dispersion of sensor information

#### 4.1.2 ロボットの行動

シミュレーションでは,ロボットは前進と右回転を使用して移動する.これらの移動量および移動量のばらつきは,実機に準じて以下のように設定する.1 歩の前進で,ロボットは平均で  $80~\mathrm{[mm]}$  移動する.また,右回転では平均で  $23~\mathrm{[deg]}$  ロボットの向きが変わり,元の位置から  $30~\mathrm{[mm]}$  後方, $40~\mathrm{[mm]}$  右に位置が変わる.これらの変位には, $x,y,\theta$  軸ごとに最大 10% のばらつきを加える.さらに,前進のときには, $-1~\mathrm{[deg]}$  から  $1~\mathrm{[deg]}$  の間でロボットの向きにばらつきを加える.移動モデルは,このばらつきの通りに実装する.

シミュレーション中,ロボットは前進してフィールドの端に 到達したら右回転し,また前進を再開するという行動をとりな がら自己位置推定を行う.ロボットは歩行中,カメラを左右に 振る.実装した歩行,カメラの動きでは,ロボットは 1 [step] につき平均で 2.5 回ランドマークの計測を行う.MCL の実装 は,1 [step] ごとに式(2)を 1 回,計測 1 回につき式(3)を 1 回実行する方法で行った.

# 4.1.3 各リセット法の $\alpha_{\rm th}$ 以外のパラメータ設定

 $\mathbf{HSR}: \mathrm{HSR}$  法では, $\eta_{\mathrm{long}}$  が 0 に近づき, $\eta_{\mathrm{short}}$  が 1 に近づくと  $\mathrm{SR}$  法の性質に近くなる.本論文では文献 [9] に基づき, $\eta_{\mathrm{long}}=0.1,\eta_{\mathrm{short}}=0.9$  とする.

ER:この環境ではパーティクルが二つ以上の集団を形成することを考慮しなくてよいため,次のような手続きを実装した.集団が二つ以上に分かれる場合,アルゴリズムは複雑になるが,本論文では扱わないこととする.以下で説明する数値は,4,5回の連続リセットでパーティクルが  $xy\theta$  空間全域に到達することを目安に設定した.この回数が少なければ連続したセンサ情報の誤りに対しロバストでなくなり,回数が多ければ誘拐状態解消に必要な膨張回数が多くなるため,以下の数値は ER 法の特性に影響を与える.しかし,同様の特性変化は閾値  $\alpha_{\rm th}$  の違いでも起こるため,以下に定める数値は定数として扱い,それらの数値に対して適切な  $\alpha_{\rm th}$  を後に決定する.

パーティクルの分布や重みが変化する度に , パーティクルの重みつき平均  $\bar{\ell}_t=(\bar{x}_t,\bar{y}_t,\bar{\theta}_t)$  と重みつき標準偏差  $\sigma_x,\sigma_y,\sigma_\theta$  を計算しておく . もし  $\beta>0$  となった場合は ,  $xy\theta$  空間中に , 各辺がそれぞれ  $x,y,\theta$  軸に平行な , 中心が  $\bar{\ell}_t$  の直方体を作成し , そのなかにランダムに重み 1/N のパーティクルを N 個配置する .  $x,y,\theta$  軸に平行な辺の長さはそれぞれ  $6\sigma_x,6\sigma_y,6\sigma_\theta$  とする . ただし , パーティクルが狭い範囲に分布している場合には膨張が遅れるため , 辺の長さの下限を  $300\,[\mathrm{mm}]$  ,  $60\,[\mathrm{deg}]$  とする .

 $\mathbf{SR}+\mathbf{ER}:\sigma_x>300\,[\mathrm{mm}]$  または  $\sigma_y>300\,[\mathrm{mm}]$  または  $\sigma_\theta>60\,[\mathrm{deg}]$  のときは  $\mathrm{SR}$  法 , それ以外のときは  $\mathrm{ER}$  法 ( 膨張方法は上記のとおり ) を用いる .  $4.5\,$ 節では , この値を変えて試行を行う .

#### 4.2 評価方法

以下のような 5 種類のテストで各手法を比較する.まず,次の二つは ML を用いる上での仮定に反しないテストである.

- position tracking problem (PTP): 全パーティクル の初期姿勢を真値  $\ell_0^*$  にして試行を開始する. 仮想ロボットは 1 回の試行で 150 [step] 歩行する.
- global localization problem (GLP): 各パーティクルは最初, X 中にランダムに配置される. 仮想ロボットは1回の試行で30 [step] 歩行する.

次の二つでは,移動モデルに反する事象を扱う.

- kidnapped robot problem ( KRP ): 全パーティクル の初期位置を ,  $\ell_0^*$  から  $\xi$  [m] 離して設定する . 初期の向き についてはランダムに設定する . ロボットは 30 [step] ごと に ,  $\xi$  [m] だけ瞬間移動する . このときのロボットの向きは ランダムに設定される .
- slipping robot problem (SRP): 姿勢追従と同様の 試行を行うが,ロボットは n [step] に一度,歩行の指令が 出ても動かない.つまり,n [step] に一度デッドレコニング が 1 [step] 分だけずれる.この状況は,近距離の誘拐,ロボットのスリップ,衝突による位置変化などに相当する.

次のテストでは,センサ情報モデルに反する事象を扱う.

• fatal sensor error problem (FSEP): 姿勢追従と同様の試行を行うが,ランドマークの識別ミスが 10 回の観測につき n 回連続で起こるようにランドマーク計測アルゴリズムを加工する.つまり,10 回のうち n 回の  $\hat{\varphi},h$  が実際とは全く異なる値になる.

試行中,ロボットが歩行を終える度に,xy平面での推定誤差

$$e_t = \sqrt{(\bar{x}_t - x_t^*)^2 + (\bar{y}_t - y_t^*)^2}$$
 (14)

を記録する.ここで  $ar x=\sum_{i=1}^N w_t^{(i)}x_t^{(i)}, ar y=\sum_{i=1}^N w_t^{(i)}y_t^{(i)}$  である.試行後に  $e_t$  から次の値を集計し,評価に用いる.

- $\bullet \bar{e}_r : e_t$  の平均値
- ullete $_r^ op$ : 区間  $[0,\lambda]$  が  $e_t$  の 95% 以上を含む場合の  $\lambda$  の最小値  $e_r^ op$  は推定の安定さを示す指標と見なせる.PTP,SRP,FSEP では全試行・全ステップの  $e_t$ ,GLP,KRP では各試行の開始 z [step] 後の  $e_t$  を集計し, $e_r^ op$ ,  $\bar{e}_r$  を求める.

# 4.3 予備的な試行

# 4.3.1 試行を行うパーティクル数について

ロボカップ 4 足ロボットリーグでは ,  $10^2$  から  $10^3$  のパーティクル数 N で MCL が利用されている . 次節以降では , ERS-210で実時間実行可能な数  $N=10^3$  でリセット法を比較する .

リセットを用いた場合との比較のために, $N=10^2,10^3,10^4$ でリセットなしの  $\mathrm{MCL}$  (以下単に  $\mathrm{MCL}$ ) について PTP,GLP の試行を行った結果を Table 1 に示す.PTP に関しては,表のように  $N=10^2$  でも安定した推定ができ, $N=10^3$  は十分といえる.一方 GLP の場合  $N=10^3$  では不十分で,推定初期でパーティクル密度不足から誘拐状態が発生する場合があり,

**Table 1** Results of GLP with MCL  $(e_r^{\top} (\bar{e}_r)[\text{mm}])$ 

	PTP	GLP (200 trials)				
N	(1500  steps)	5[step] after	15[step] after	30[step] after		
$10^{2}$	80(39)	2483(980)	2326(892)	2619(819)		
$10^{3}$	100(54)	1011(404)	964(379)	1082(338)		
$10^{4}$	102(45)	335(165)	260(138)	247(130)		

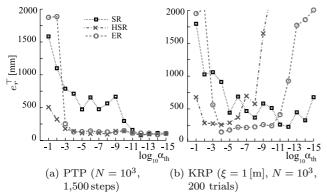


Fig. 6 Results with various  $\alpha_{\rm th}$ 

# $e_r^{\top}$ が $1 [\mathrm{m}]$ 程度と推定に支障が出た.

# 4.3.2 リセット閾値 $lpha_{ m th}$ と精度 , リセットの頻度の関係

 $lpha_{
m th}=10^{-1},10^{-2},\dots,10^{-15}$  と  ${
m SR}\cdot{
m HSR}\cdot{
m ER}$  法の組み合わせで,PTP における  $e_r^{
m T}$  の比較を行った. ${
m Fig.}\,{
m 6}\,({
m a})$  に  $e_r^{
m T}$  の値を示す. ${
m SR}$ , ${
m HSR}$ , ${
m ER}$  法ではそれぞれ  $lpha_{
m th}\leq 10^{-11},10^{-3},10^{-4}$  で  $e_r^{
m T}<100\,[{
m mm}]$  となった.このときのランドマーク計測回数に対するリセット回数の割合は,それぞれ 0.5,0.6,2.5%であった. ${
m HSR}$  法と  ${
m SR}$  法については,リセットの頻度が 1% 以上であると, $e_r^{
m T}>250\,[{
m mm}]$  となり,推定への悪影響が大きかったが, ${
m ER}$  法の場合は上記のように 2.5% でも安定した推定が可能であった. ${
m ER}$  法の場合はパーティクルの平均姿勢  $\ell$ の変化が  ${
m SR}$  法よりも少ないためであると考えられる.

次に, $\xi=1.0\,[\mathrm{m}]$  の KRP で,試行開始から  $30\,[\mathrm{step}]$  後の  $e_r^{\mathsf{T}}$  を比較する.この条件では,必要なリセットが起きないと  $30\,[\mathrm{step}]$  後になっても誤りが解消されない確率が高くなる反面,不必要なリセットが起きると精度に悪影響が起きる.そのため, KRP に適した閾値  $\alpha_{\mathrm{th}}$  を用いるとほかのテストでも良い結果 が得られると考えられる.

Fig. 6 (b) に結果を示す.HSR については  $10^{-2} \leq \alpha_{\rm th} \leq 10^{-6}$ ,ER については  $10^{-4} \leq \alpha_{\rm th} \leq 10^{-11}$  まで安定した推定(ここでは  $e_r^{\top} < 500~[{\rm mm}]$  を指すとする)が可能であることが分かる.SR については図を見る限り,安定した推定が可能な $\alpha_{\rm th}$  の範囲は HSR 法,ER 法よりも狭いようである.

# 4.4 シミュレーション結果

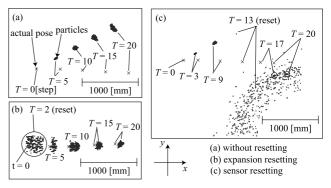
 $\mathrm{SR}\cdot\mathrm{HSR}\cdot\mathrm{ER}$  法では,それぞれ  $\alpha_{\mathrm{th}}=10^{-12},10^{-4},10^{-4}$  のときに最小の  $e_r^{\mathsf{T}}$  が得られた.これらの閾値で前述の全テストを行った.また,MCL, $\mathrm{SR}+\mathrm{ER}$  法についてもテストを行った. $\mathrm{SR}+\mathrm{ER}$  法では  $\alpha_{\mathrm{th}}=10^{-4}$  を用いた.

# 4.4.1 Position Tracking Problem (PTP)

PTP , SRP , FSRP で得られた  $\bar{e}_r, e_r^{\top}$  を Table 3 に示す . 表のように , ER , ER+SR 法の  $e_r^{\top}, \bar{e}_r$  ( 斜字で表示 ) が大きかったことが分かる . これは , 膨張リセットでは大きい閾値が使え

**Table 2** Results of GLP  $(N = 10^3, 200 \text{ trials}, e_r^{\top} (\bar{e}_r) [\text{mm}])$ 

Method	5[step] after	15[step] after	30[step] after
SR	890(308)	492(196)	310(150)
HSR	894(304)	386(181)	249(138)
ER	656(247)	275(116)	152(83)
SR+ER	508(200)	235(110)	142(82)



**Fig. 7** Recovery from 30 [deg] error of  $\theta$ 

たため、その分リセットが起こりやすかったからであった.

# 4.4.2 Global Localization Problem (GLP)

GLP で得られた結果を Table 2 に示す.Table 1 と比較すると,同数のパーティクルを用いた場合には,どのリセット方法も MCL よりは良い結果を得ている.特に,ER 法と SR+ER 法については, $15[\mathrm{step}]$  以降に  $N=10^4$  の MCL と同等以上の結果が得られた.

#### 4.4.3 Slipping Robot Problem (SRP)

Table 3 から 、どの頻度 n でも ER 、ER+SR 法(数値を太字で表示)に優位性があることが分かる.この理由を説明するため,SRP と同様な状況を作成し,MCL,SR 法,ER 法でのパーティクルの学動を調べたものを Fig.7 に示す.この図はパーティクルの向きに 30 [deg] の誤差が生じ,その後ロボットが前進(図の右方向)したときのパーティクルの学動を示したものである.Fig.7 (a) のように,リセットを用いないとパーティクルは xy 平面上で歩行ごとに誘拐状態が大きくなる.一方,SR 法・ER 法では Fig.7 (b) ,(c) のように途中でリセットが起こり,誘拐状態が解消されている.ただし,SR 法では大きい閾値  $\alpha_{th}$  が使用できないため,リセットの発動が遅れている.リセットの遅れは,大きな閾値  $\alpha_{th}$  を用いる HSR 法でも確認された.

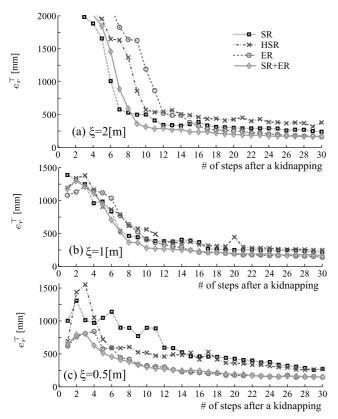
# 4.4.4 Kidnapped Robot Problem (KRP)

誘拐後の歩数を横軸, $e_r^ op$  を縦軸にして結果を  ${f Fig. 8}$  に示す. KRP における MCL 結果については,試行開始からの歩数に 関わらず  $ar e_r=1.5, e_r^ op=3\, [{f m}]$  程度であり,図からは省いた.

KRP では、どの誘拐の距離  $\xi$  でも SR+ER 法がすばやく誘拐状態を解消し、さらに解消後の誤差も他より小さかった、SR 法では誘拐状態の解消が早く、ER 法では解消後の誤差が SR 法、HSR 法よりも小さかったが、SR+ER 法ではその両方の良い性質が見られた.

# 4.4.5 Fatal Sensor Error Problem (FSEP)

Table 3 のように, MCL による結果(太字で表示)がほかよりも良く,誤ったセンサ情報によるリセットが精度に悪影響



**Fig. 8** Results of KRP  $(N = 10^3, 200 \text{ trials for each } \xi)$ 

**Table 3** Results of PTP, SRP and FSEP  $(N = 10^3, 1500 \text{ steps})$ 

(a) $e_r$ [mm]						
problems	$methods \rightarrow$	MCL	SR	HSR	ER	SR+ER
	$lpha_{ m th}  ightarrow$	0	$10^{-12}$	$10^{-4}$	$10^{-4}$	$10^{-4}$
PTP		54	46	43	72	71
SRP	n = 3	1220	312	301	235	245
	n = 5	461	218	248	179	200
	n = 10	236	141	173	121	129
FSEP	n = 1	47	167	66	96	102
	n = 2	56	558	69	124	165
	n = 3	54	726	202	219	320
	•	•	•	•	•	

(b) $e_r^{ op}$ [mm]						
problems	$methods{\rightarrow}$	MCL	SR	HSR	ER	SR+ER
	$lpha_{ m th}  ightarrow$	0	$10^{-12}$	$10^{-4}$	$10^{-4}$	$10^{-4}$
PTP		100	76	93	132	141
SRP	n = 3	2989	692	607	419	419
	n = 5	1276	428	523	313	360
	n = 10	721	302	320	213	228
FSEP	n = 1	116	752	153	187	195
	n=2	143	2427	181	272	344
	n=3	120	2745	873	625	906

を与えることが分かる.HSR 法の結果が他のリセット法よりも良いのもリセットが起こりにくいからであった.ER 法のリセット頻度は,SR 法と同程度であったが,パーティクルの平均姿勢が変化しないため,HSR 法に準じる値が得られた.

## 4.5 SR+ER 法の閾値と特性の変化

最後に, SR+ER 法の閾値と SR+ER 法の特性の関係について KRP で調査した. Table 4 は, 150 [mm], 30 [deg] の半分,

**Table 4** Results of KRP with SR+ER on various thresholds  $(N=10^3, 200 \text{ trials}, \alpha_{\rm th}=10^{-4}, e_T^\top (\bar{e}_T) [\text{mm}])$ 

$\xi[m]$	thresholds	5[step]	15[step]	30[step]
		after	after	after
0.5	150[mm], 30[deg]	401(192)	213(108)	150(82)
	300[mm], 60[deg]	512(221)	247(115)	150(81)
	600[mm], 120[deg]	602(227)	223(107)	156(81)
1	150[mm], 30[deg]	806(242)	258(120)	171(88)
	300[mm], 60[deg]	942(322)	247(116)	164(83)
	600[mm], 120[deg]	874(345)	257(119)	158(83)
2	150[mm], 30[deg]	693(221)	227(107)	161(86)
	300[mm], 60[deg]	1845(414)	241(120)	174(88)
	600[mm], 120[deg]	2032(719)	298(122)	158(87)

倍の閾値で, $\xi=0.5,1,2\,[\mathrm{m}]$  に対して得た結果である.結果には,これらの範囲の閾値では  $15\,[\mathrm{step}]$  以降の結果に大差なく,誘拐状態の解消後の誤差が小さくできるという  $\mathrm{ER}$  法の特長が表れている.また, $150\,[\mathrm{mm}]$ , $30\,[\mathrm{deg}]$  の場合, $5\,[\mathrm{step}]$  時にどの  $\xi$  に対しても非常に良好な結果が得られていることが分かる.しかしその代わり,FSEP において  $\mathrm{SR}$  法のように悪い結果が得られると容易に予想される.

### 4.6 考察

上記の結果はあくまで特定の環境で得られたものであるが, これらの結果から一般的に次のことが考えられる.

• Table 1 と Table 2 を比較すると分かるように,GLP ではリセット法を用いた方が,用いないよりも 1 桁以上少ないパーティクル数で同等以上の結果が得られることがある.これは,GLP から誘拐状態に発展しないための数 N より,リセット法が KRP を解決できるための数 N が少なかったからである.特に,ER 法を用いると近距離の誘拐状態の発生が問題とならないため,必要なパーティクル数を確実に減らせると考えられる.

このことは,より広い領域の自己位置推定を行う場合や計算資源の制限がある場合に有効である.ただし計算量削減のためには,リセット法をMCL程度の計算量(オーダにして $\mathcal{O}(N)$ から $\mathcal{O}(N\log N)$ 程度)で実装する必要がある.

- センサ情報に深刻なバースト誤りが発生しない限り, ER 法 は近距離の誘拐状態に対してパーティクルの分布を広げすぎないため, ロボットのスリップのような問題に対して ER 法は有効に機能する.
- HSR 法における式(11)による  $\beta$  の求め方は,センサ情報の誤りに対しては SR 法より非常に有効であるが,誘拐状態 ( KRP , SRP ) の解消に対しては SR 法に対する利点が見られない.それは,HSR 法ではセンサ情報とパーティクル分布の矛盾が連続しない限りリセットを抑制することが,誘拐状態に対するリセットの発動を遅らせてしまうからである.これは特に Fig. 8 (a) で誤差の減少が SR 法より遅れていることによく表れている.ただし,一度リセットが起こった後は ER 法よりも急速に誤差を小さくできる.
- ER 法にはリセット時のセンサ情報をパーティクルの再配置に用いない不利があり、シミュレーションでは遠距離の誘拐状態の解消が SR 法に比べて遅れるが、SR+ER 法は ER 法のこの欠点を補っている.遠距離の誘拐状態だけ発生し、かつセンサ情報に想定外の雑音が発生しない場合、SR 法は SR+ER 法

よりも有利である.しかし,そのような状況は考えにくいため, SR+ER 法のほうがより多くの状況で有効であると考えられる.

# 5. お わ り に

ML, MCL のための膨張リセット法(ER 法), 既存のセンサリセット法(SR 法)と膨張リセット法を組み合わせる方法(SR+ER 法)を提案した.ML, MCL が推定の誤りを起こしやすい事象(様々な距離の誘拐ロボット問題, センサ情報の誤り)をシミュレーション環境に再現した.そして,それらの事象に対する MCL, SR 法,履歴センサリセット法(HSR 法),ER 法,SR+ER 法の挙動を調査した.結果とその考察は 4章の通りであるが,さらに簡潔に述べると,誘拐のない姿勢追従にはリセットは不必要,近距離の誘拐に対しては ER 法が有効であり,SR 法と ER 法を組み合わせることであらゆる距離の誘拐に対して機能するという結論に至った.

#### 参考文献

- [1] K. Asanuma, et al.: "Development of a Simulator of Environment and Measurement for Autonomous Mobile Robots Considering Camera Characteristics," In D. Polani, et al. (Eds.): RoboCup 2003: Robot Soccer World Cup VII, pp.446–457, 2004.
- [2] W. Burgard, et al.: "Estimating the Absolute Position of a Mobile Robot Using Position Probability Grids," In Proc. of the Thirteenth National Conference on Artificial Intelligence, vol.2, pp.896–901, 1996.
- [3] W. Burgard, et al.: "Integrating Global Position Estimation and Position Tracking for Mobile Robots: the Dynamic Markov Localization Approach," In Proc. of IEEE/RSJ IROS, pp.730– 735, 1998.
- [4] P. Buschka, et al.: "Fuzzy Landmark-Based Localization for a Legged Robot," In Proc. of IEEE/RSJ IROS, pp.1205–1210,

2000.

- [5] Z. Crisman, et al.: "Team description: UW Huskies-02," In Proc. of International RoboCup Symposium, CD-ROM, 2002.
- [6] F. Dellaert, et al.: "Monte Carlo Localization for Mobile Robots," In Proc. of IEEE ICRA, pp.1322–1328, 1999.
- [7] D. Fox, et al.: "Monte Carlo Localization: Efficient Position Estimation for Mobile Robots," In Proc. of AAAI, pp.343–349, 1999.
- [8] D. Fox: "Adapting the Sample Size in Particle Filters Through KLD-Sampling," International Journal of Robotics Research, vol.22, no.12, pp.985–1004, 2003.
- [9] J. Gutmann and D. Fox: "An Experimental Comparison of Localization Methods Continued," In Proc. of IEEE/RSJ IROS, pp.454–459, 2002.
- [10] T. Ishimura, et al.: "An Open Robot Simulation Environment," In D. Polani, et al. (Eds.): RoboCup 2003: Robot Soccer World Cup VII, pp.621–627, 2004.
- [11] K. Kwok, et al.: "Adaptive Real-time Particle Filters for Robot Localization," In Proc. of IEEE ICRA, pp.2836–2841, 2003.
- [12] S. Lenser, et al.: "Sensor Resetting Localization for Poorly Modelled Robots," In Proc. of IEEE ICRA, pp.1225–1232, 2000.
- [13] T. Röfer: "An Architecture for a National RoboCup Team," G.A. Kaminka et al. (Eds.): RoboCup 2002: Robot Soccer World Cup VI, pp.417–425, 2003.
- [14] S. Thrun, et al.: "Robust Monte Carlo Localization for Mobile Robots," Artificial Intelligence Journal, vol.128, no.1–2, pp.99–141, 2001.
- [15] R. Ueda, et al.: "Uniform Monte Carlo Localization Fast and Robust Self-localization Method for Mobile Robots," In Proc. of IEEE ICRA, pp.1353-1358, 2002.
- [16] 藤田: "4 脚ロボットリーグの技術課題と展望", 日本ロボット学会誌, vol.20, no.1, pp.15-19, 2002.
- [17] 大橋: "4 足口ボットリーグのとりくみ", 日本ロボット学会誌, vol.20, no.1, pp.45–46, 2002.
- [18] 友納,油田: "不正確さを許すマップにおける移動ロボットの自己位置推定",日本ロボット学会誌,vol.20,no.4,pp.425-436,2002.



#### 上田隆一 (Ryuichi Ueda)

1978 年 2 月 16 日生・2001 年東京大学工学部精密機械工学科卒業,2003 年東京大学大学院工学系研究科精密機械工学専攻修士課程修了・同年,同専攻博士課程進学・2004 年中退ののち同専攻助手,現在に至る・ロボカップ4 足ロボットリーグを題材として自律移動ロボットの状態推定,行動決定に関す

る研究に従事・日本ロボット学会研究奨励賞・IEEE , 精密工学会の正会員・ (日本ロボット学会正会員)



### 新井民夫 (Tamio Arai)

1947 年 8 月 4 日生 . 1970 年東京大学工学部精密機械工学科卒業,1977 年同博士課程修了 . 工学博士 . 1979 年英国エディンバラ大学人工知能学科研究員 . 1987 年東京大学工学部精密機械工学科教授 . 自動組立,移動ロボットの協調,自律分散システムなどの研究に従事・精密工学会論文賞,IMS 賞な

ど.IEEE, CIRP などの正会員. (日本ロボット学会正会員)



## 浅沼和範 (Kazunori Asanuma)

1977 年 9 月 13 日生・2001 年中央大学理工学部精密機械工学科卒業・同年,同大学大学院理工学研究科精密機械工学専攻博士課程前期課程進学,2003年同専攻修了・現在,日立ソフトウェアエンジニアリング株式会社に勤務・



#### 大隅 久 (Hisashi Osumi)

1962 年 3 月 5 日生.1988 年東京大学大学院工学系研究科博士課程中退.同年東京大学精密工学科助手,1991 年同講師,1993 年同助教授,1994 年中央大学理工学部精密機械工学科助教授,2000 年教授,ロボットの機構,制御の研究に従事.工学博士.精密工学会,日本機械学会,計測自動制御学会,



(日本ロボット学会正会員)



# 梅田和昇 (Kazunori Umeda)

1967年2月6日生、1989年東京大学工学部精密機械工学科卒業,1994年同大学大学院精密機械工学専攻博士課程修了,博士(工学).同年中央大学理工学部精密機械工学科専任講師,1998年より同助教授、ロボットビジョン,センサフュージョン,マン・マシン・インタフェースの研究に従事、精密

工学会,日本機械学会,電子情報通信学会,情報処理学会,日本時計学会,IEEE の会員. (日本ロボット学会正会員)